



DOI:10.12404/j.issn.1671-1815.2403476

引用格式:杨博璇,王志飞,李樊,等.基于人工智能的高速铁路站台门结构变形的预测[J].科学技术与工程,2025,25(6):2548-2553.

Yang Boxuan, Wang Zhifei, Li Fan, et al. Prediction of platform door structure deformation of high-speed railway based on artificial intelligence[J]. Science Technology and Engineering, 2025, 25(6): 2548-2553.

基于人工智能的高速铁路站台门结构变形的预测

杨博璇¹, 王志飞^{2*}, 李樊², 王浩东², 李帅²

(1. 中国铁道科学研究院研究生部, 北京 100081; 2. 中国铁道科学研究院集团有限公司电子计算技术研究所, 北京 100081)

摘要 为了解决运营线路站台门结构变形难以实时监控的问题,精准预测列车过站时高速铁路站台门的结构变形数据,采用基于人工智能的神经网络方法,选取 210 种不同车长、阻塞比、安装距离和车速的站台门结构变形数据作为网络模型训练样本,运用 CNN(convolutional neural network)和基于 K-Fold(K-fold cross-validation)的 GRNN(general regression neural network)两种神经网络模型,建立了不同工况下的高速铁路站台门结构变形的预测模型,并与剩余样本数据进行对比验证。研究表明,两种模型均可有效预测铁路站台门结构运维数据,在预测精度上,基于 K-Fold 优化的 GRNN 模型优于 CNN 模型,基于 K-Fold 优化的 GRNN 模型的预测均方差能够维持在 0.22 之内,均方根误差维持在 0.27 之内,处于研究领域的领先水平。基于 K-Fold 优化的 GRNN 模型能够较好预测列车过站时的站台门结构形变量,为高速铁路站台门的设计与运维提供数据参考。

关键词 神经网络; 回归预测; 站台门运维; 高速铁路站台门

中图分类号 U291.6⁺5;

文献标志码 A

Prediction of Platform Door Structure Deformation of High-Speed Railway Based on Artificial Intelligence

YANG Bo-xuan¹, WANG Zhi-fei^{2*}, LI Fan², WANG Hao-dong², LI Shuai²

(1. Graduate Department, China Academy of Railway Sciences, Beijing 100081, China;

2. Institute of Computing Technology, China Academy of Railway Sciences, Beijing 100081, China)

[Abstract] In order to solve the problem of real-time monitoring and accurate prediction of structural deformation of platform doors on high-speed railway lines, an artificial intelligence-based neural network method was used. Structural deformation data of platform doors, involving 210 different conditions of train length, blocking ratio, installation distance, and speed, were selected as training samples for the network model. Two neural network models, CNN(convolutional neural network) and K-Fold(K-Fold cross-validation) optimized GRNN(general regression neural network), were used to establish predictive models for platform door structural deformation under different working conditions of high-speed railways. These models were compared and verified with the remaining sample data. The research shows that both models effectively predict the operation and maintenance data of railway platform door structures. The K-Fold optimized GRNN model is superior to the CNN model in prediction accuracy. The Mean Square Error of the K-Fold optimized GRNN model is maintained within 0.22, and the Root Mean Square Error is within 0.27, which is at the leading level in the field. The K-Fold optimized GRNN model better predicts the structural deformation of platform doors when trains pass, providing data references for the design and maintenance of high-speed railway platform doors.

[Keywords] neural network; regression prediction; platform door operation and maintenance; high-speed railway platform doors

目前,中国高速铁路最高运营速度 350 km/h,高速列车在过站时,由于空气的黏性作用使周围的空气被列车表面带动并随之一起作用,产生了列车风^[1]。随着高铁的不断发展,列车的运营速度朝着 400 km/h 级发展,列车风的影响将更加突出^[2]。站台门通过实现乘客与列车行轨的物理隔离,降低了

列车风对站台的影响,同时也给自身结构的负载能力带来了挑战^[3]。由于站台门安装在站台边缘,发生较大的结构变形会导致门体侵入限界,甚至脱落掉入轨道,引发重大安全事故。除此之外,站台门的结构形变还可能进一步导致控制系统失灵等问题,容易引发站台乘客人身伤亡等重大安全事故的

收稿日期: 2024-05-11; 修订日期: 2024-12-17

基金项目: 国家自然科学基金(U21A201646); 中国铁道科学研究院集团有限公司重点项目(2023YJ129)

第一作者: 杨博璇(1999—),女,汉族,河北石家庄人,硕士研究生。研究方向:智能轨道交通与安全防护技术。E-mail: yyy202302@163.com。

* 通信作者: 王志飞(1981—),男,汉族,内蒙古东胜人,博士,研究员。研究方向:交通运输工程与控制。E-mail: wfbuaa@126.com。

投稿网址: www.stae.com.cn

发生^[4]。

随着全国高速铁路网的逐步形成和发展、对站台门的需求量不断增加,总体运维成本也在迅速增长。文献[5]对站台门轨旁事故进行分析,强调了站台门结构变形侵入限界的风险;文献[6-7]针对运营线路上站台门结构形变难以实时监控的问题,提出了高铁站台门有限元模型加载方法。文献[8]对高速列车的气动效应进行了数值研究,部分学者对站台门的使用寿命产生了预测,没有对站台门形变量预测的相关研究。站台门一旦在列车正常运行过程中出现故障,轻则影响乘客的正常出行,重则产生重大安全事故,严重损害乘客的生命财产安全;同时由于其检修项目种类繁多、技术门槛较高,人力资源花费较大^[9],定时对站台门进行安全检修不仅不能完全防范故障的产生,更会消费巨大的经济与人力成本。为了预防列车过站时站台门结构变形产生的安全事故、为站台门的前期设计提供结构强度数据参考、节省高速铁路站台门的运维费用,解决运营线路上站台门结构形变难以实时监控的问题,基于人工智能的站台门结构变形的研究迫在眉睫。

为了更有效地预防站台门结构变形引发的安全事故,降低站台门故障发生率、提升站台门形变量预测的准确性,本文研究提出基于人工智能的高速铁路站台门结构变形的预测方法,利用结构变形数据对 CNN(convolutional neural network)网络模型和基于 K-Fold(K-Fold cross-validation)算法进行参数优化的 GRNN(general regression neural network)网络模型进行训练,最后将两种网络模型的预测值与真实值进行对比。

1 基础理论

1.1 CNN 神经网络模型

CNN 神经网络是一种深度学习模型,通过卷积层和池化层有效处理图像数据,广泛用于图像分类、目标检测等领域。其层次结构包括输入层、多个卷积-池化层和全连接层^[10]。CNN 神经网络结构如图 1 所示。图 1 中 w 为卷积核的权重参数,用于与输入特征图进行卷积操作,以提取不同层次的特征。通过网络训练会被不断优化,以增强对目标数据的识别和分类能力。

卷积层是神经网络的核心组件,通过卷积运算提取输入数据中的特征,通用的卷积公式为

$$s(i, j) = (\mathbf{X} * \mathbf{W})(i, j) + \mathbf{b} \quad (1)$$

式(1)中: i 为输入特征图的行索引; j 为输入特征图的列索引; $s(i, j)$ 为卷积结果中位置 (i, j) 的值; \mathbf{W}

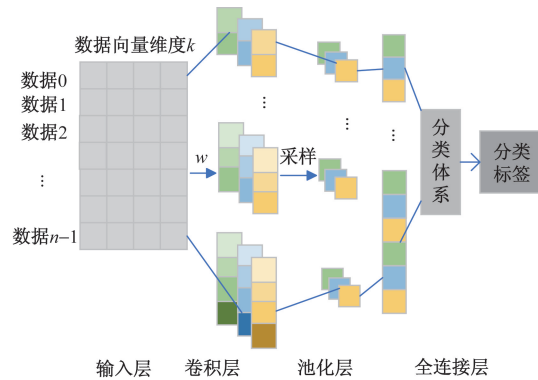


图1 CNN神经网络结构图

Fig. 1 CNN neural network structure diagram

为卷积核; \mathbf{X} 为输入数据; \mathbf{W} 的维度与输入数据向量维度 K 保持一致; \mathbf{b} 为偏置项。

数据从卷积层传输到池化层还需经过激励函数处理,CNN网络选用 ReLU 函数作为激活函数,函数一般形式为

$$f(x) = \frac{1}{1 + e^{-x}} \quad (2)$$

式(2)中: x 为某一层神经网络的输出。

池化层分为用于减少卷积层输出特征向量、防止过拟合的平均池化层和最大池化层,一般采用最大值 max 函数或平均值 average 函数进行池化操作,在本文中使用 max 函数来压缩池化层数据。

全连接层将之前卷积层和池化层提取的特征进行收集,再选用 Softmax 函数将输出值进行分类^[11]。

在对铁路站台门结构运维数据进行试验与预测时,算法目标不再是预测输入图像的类别,而是预测一个连续的目标值。因此将算法的最后一层全连接层的输出形式修改为一个单一的连续值,然后使用一个回归损失函数来训练网络。

常见的损失函数有平均误差损失函数 L_1 、均方误差损失函数 L_2 、函数 SSIM(structural similarity index)等,考虑到输入的数据形式一般采用均方误差函数损失函数,函数形式为

$$L_2 = \frac{1}{N} \sum_{a=1}^N (x_a - y_a)^2 \quad (3)$$

式(3)中: N 为数据的样本数量; x_a 为第 a 个样本的真实值; y_a 为第 a 个样本的预测值。

1.2 基于 K-Fold 优化的 GRNN 神经网络模型

GRNN 属于径向基神经网络的一种变形形式,该网络模型没有训练过程,主要通过模式层的平滑因子进行优化来获得好的输出结果^[12],GRNN 的神经网络结构图如图 2 所示。

输入层实现数据的输入过程,并将输入数据传




图2 GRNN神经网络结构图

Fig. 2 GRNN neural network structure diagram

递至模式层,该层的节点数为输入数据的特征维度。

模式层一般用高斯函数对输入数据进行处理,节点数为训练样本的个数,具体计算公式为

$$g_i = \exp\left(-\frac{\|x_i - x\|}{2\sigma^2}\right) \quad (4)$$

式(4)中: \$x_i\$ 为训练样本; \$x\$ 为学习样本; \$\sigma\$ 为平滑因子; \$g_i\$ 为训练样本与学习样本之间的相似度。

假设输出样本维度为 \$j\$, 则求和层节点数为 \$j + 1\$, 其中一个节点输出 \$s_d\$, 为模式层输出的算术和^[13], 其余节点输出 \$s_{ni}\$ 均为模式层输出的加权和, 计算公式为

$$s_d = \sum_{i=1}^n g_i \quad (5)$$

$$s_{ni} = \sum_{i=1}^n w_{ij} g_i \quad (6)$$

式中: \$w_{ij}\$ 为加权系数。

输出层的节点数为输出样本维度 \$O_j\$, 主要根据求和层求出的算术和与加权和进行计算输出, 计算公式为

$$O_j = \frac{s_{ni}}{s_d} \quad (7)$$

影响 GRNN 模型准确度的因素主要是模式层的平滑因子 \$\sigma\$, \$\sigma\$ 取值偏大或偏小会导致模型出现欠拟合现象或过拟合现象。对于不同的训练样本数据, \$\sigma\$ 的最佳取值差异较大。在 GRNN 模型训练中 \$\sigma\$ 的最佳值通常难以寻求, 为尽量提升 GRNN 模型的准确度, 本文研究选用 K-Fold 算法对 \$\sigma\$ 进行优化。

交叉验证即将数据集 Data 划分成训练集和验证集两部分^[13], 首先用训练集训练模型, 然后用测试集验证模型, 以此来作为评价模型的性能指标。

K 重交叉验证的示意图如图 3 所示, 将训练集数据 Data 分为 \$k\$ 份, 用 \$k - 1\$ 份数据进行模型训练, 剩余一份数据对模型进行评估, 则共有 \$k\$ 种分割方式。对 \$k\$ 种训练集数据分别进行训练, 取评估时模型准确度最高的分割方式和 \$\sigma\$ 取值作为 Data 数据

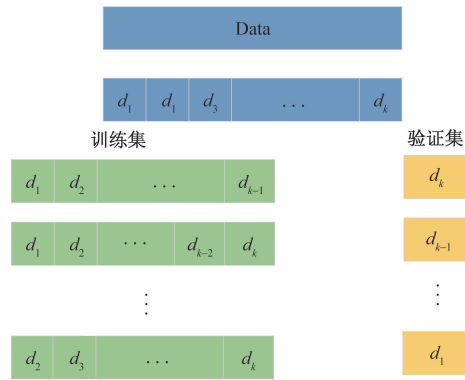


图3 K重交叉验证示意图

Fig. 3 K-Fold cross verification diagram

集的最优划分, 用最优化数据训练出来的模型可视为 K 重交叉验证的最优模型, 此时的参数取值可视为当前训练集数据下的最优值。

2 结构变形智能预测模型

将列车长度、阻塞比、站台门安装距离、列车速度作为输入层数据, 站台门结构形变量作为神经网络的输出数据。为保证训练模型的训练结果的准确性, 从 210 组数据中选取 189 组作为训练数据, 余下 21 组作为验证数据, 训练与验证数据比例为 9: 1。列取 8 组验证数据, 如表 1 所示。

表1 样本验证数据表

Table 1 Sample validation data table

序号	车长/ m	阻塞比	安装距离/ mm	车速/ (km·h ⁻¹)	形变量/ mm
1	101.4	5.5	700	200	6.99
2	151.4	5.78	1 000	100	2.12
3	151.4	5.78	1 000	120	2.69
4	187.0	5.93	700	200	8.29
5	201.4	6.25	1 500	140	4.13
6	201.4	6.25	1 500	160	4.68
7	187.0	6.24	1 000	140	3.83
8	95.8	6.45	1 200	120	4.93

2.1 CNN 网络模型建立、训练与评估

2.1.1 模型建立

在 CNN 算法中, 训练样本不能直接使用, 需要经过归一化处理和数据维度转换后作为输入数据再进行模型的训练与验证。

首先采用最大最小归一化函数 (mapminmax) 对样本数据归一化, 将其映射到 \$[-1, 1]\$ 区间 (在后续步骤中, 预测出的结果需要反归一化回原始数据的范围), 使 4 种拥有不同单位和不同范围的输入数据 (车长、阻塞比、站台门安装距离、列车速度) 在模型训练中拥有相同权重。

其次,CNN 模型训练采用的是四维数据,因此需使用 MATLAB 函数 Reshape 将用于训练的仿真二维数据转换为四维数据。

最后,利用 MATLAB 自带的 Deep Learning Toolbox 工具箱函数构建 CNN 模型,为保证模型的训练效果,需根据输入实际数据卷积核大小进行设置。经过反复多次试验与调整,最终确定模型参数如表 2 所示。

函数 InitialLearnRate 控制模型参数更新的步长,设置为 0.001;最大迭代次数参数 MaxEpochs 设置为 120,表明模型经过 120 次完整的训练;使用小批量数据进行训练对模型进行优化,设置小批量数据大小 MiniBatchSize 为 32;数据混洗(Shuffle)、每个迭代重新混洗(every-epoch)参数设定训练数据的混洗策略,设置 every-epoch 参数在每次迭代开始时重新混洗训练数据,增加训练的随机性。

表 2 CNN 模型参数取值

Table 2 CNN model parameter values

参数更新步长	最大迭代次数	小批量数据	Shuffle/ every-epoch
0.1	120	32	1

2.1.2 模型训练与评估

图 4 是利用表 2 各项参数调整后的训练过程,展示了均方根误差(root mean squared error, RMSE)和迭代次数的关系。可见当迭代次数达到 400 次时,平均方根误差曲线趋于稳定,此时达到训练要求。

通过输入验证数据对训练好的 CNN 模型进行准确度评估,使用 MATLAB 作图对比真实值和 CNN 模型的预测值,模型的直观预测效果如图 5 所示,可见真值曲线与 CNN 模拟曲线走向一致。

2.2 K-Fold GRNN 网络模型建立、训练与评估

在预测站台门结构形变量数据时,为降低真实数据与模拟数据的误差,需要对 GRNN 模型的 σ 参数优化求解,本节采用 K-Fold 方法进行求解。




图 4 均方误差和迭代次数的关系

Fig. 4 Relation between mean square error and number of iterations

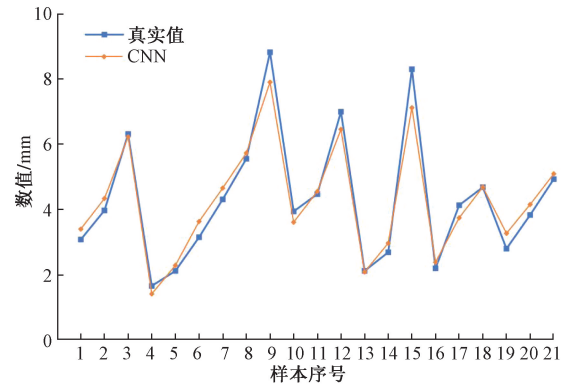


图 5 真实值与 CNN 模型预测值对比

Fig. 5 Comparison between the real value and the predicted value of CNN model

2.2.1 模型建立

分析站台门型变量影响因素,取车长、阻塞比、车速和安装距离 4 项指标因素作为网络输入,以站台门型变量指标因素作为网络输出,构建 GRNN 模型网络。

对样本数据的前 189 组进行划分,取 188 组数据作为交叉验证的训练集,剩余 1 组作为验证集,共有 189 种划分方式。K-Fold 方法的选取参数如表 3 所示,设置 σ 参数取值区间 $[-1, 1]$,变化步长为 0.1,通过循环求解真实数据与模拟数据误差最小的情况,此时的取值为最优值,利用该最优参数值和对应的划分方式训练得到的模型为最优模型。

表 3 K-Fold 参数选取

Table 3 K-Fold parameter selection

σ 取值区间	σ 变化步长
$[-1, 1]$	0.1

2.2.2 模型训练与评估

训练样本同样需要用 mapminmax 函数经归一化后才能作为 GRNN 模型训练函数中作为函数输入使用。取 K-Fold 方法计算得到的最佳 σ 、最佳划分方式作为函数参数输入,命名得到的 GRNN 模型

为 net。

通过输入验证数据对训练好的 GRNN 模型进行准确度评估,图 6 为站台门结构形变量真实值与基于 K-Fold 算法的 GRNN 模型预测值的对比,可见预测曲线与模拟曲线走向一致。

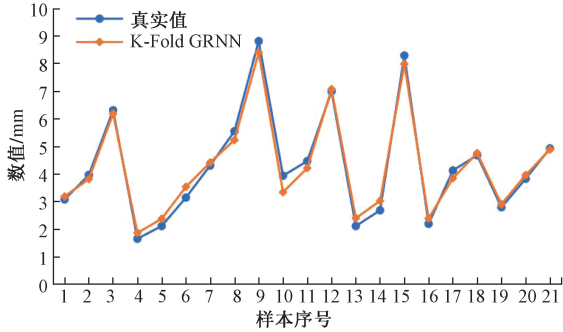


图 6 真实值与基于 K-Fold 优化的 GRNN 模型预测值对比
Fig. 6 Comparison between the real value and the predicted value of GRNN model based on K-Fold optimization

3 预测结果对比分析

站台门结构运维数据的真实值与两种网络模型的预测值的对比如图 7 所示。从细节看,两个模型均在个别相同点位出现了较明显的误差;从整体看,两条模拟曲线均贴合真实曲线。

2 种模型对于 8 组数据的预测误差如表 4 所示,观察发现第 3 组数据的整体误差较大,考虑到两种模型的预测彼此接近,可判断为真实值记录时存在误差导致;在第二组数据的预测上,CNN 模型拟合较好而 GRNN 模型误差较大。除模拟误差较大的第 2 组数据外其余 6 组数据的预测误差均保持在 11%、4% 和 8% 以内,推测可知 GRNN 模型在训练过程中偶尔出现样本分布不均匀导致极个别输入数据的预测中表现不佳的情况,CNN 模型则较稳定。

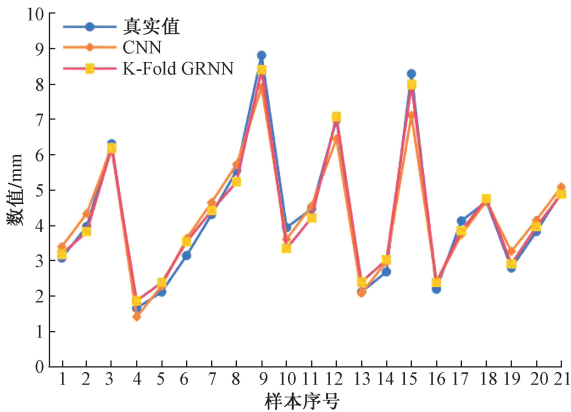


图 7 实际值与模型预测值对比

Fig. 7 Comparison of actual values with model predictions

分别计算两种模型的预测数据与仿真数据之间的均方差(mean absolute error, MEA)和均方根误差 RMSE,计算结果如表 5 所示。

$$MEA = \frac{1}{n} \sum_{i=1}^n |x_i - x| \tag{8}$$

$$RMSE = \sqrt{\frac{1}{n} \sum_{i=1}^n (x_i - x)^2} \tag{9}$$

式中: n 为样本数量; x_i 为预测值; x 为真实值; i 为样本序号。

利用 K-Fold 算法进行参数优化后的 GRNN 模型的预测均方差和均方根误差都最小,分别是 0.223 9 和 0.265 2。从模拟结果上看基于 K-Fold 算法优化的 GRNN 模型的整体预测精度优于 CNN 模型。

国内站台门形变量预测以往通常采用流体力学、有限元分析和试验验证相结合的方式,通过模拟列车过站时的气动载荷进行结构变形的有限元分析,最终进行线路实验验证。当前已有的站台门型变量预测方式与机器学习方式的最优精度对比如表 6 所示,通过有限元分析的方式进行高铁站台门型变量预测的最大均方差维持在 0.38 内,均方根误差为 0.28,城际列车站台门型变量预测最大均方差维持在 0.43 内,均方根误差为 0.31^[6-7],与国内站台门结构形变的已有研究成果对比,本文通过机器学习算法对站台门形变预测的最高精度模型为基于 K-Fold 的 GRNN 模型,预测均方差维持在 0.23 以内,均方根误差为 0.27,低于有限元分析仿真算法,大幅提升了结构形变预测的准确度,为高速铁路

表 4 CNN 与 K-Fold GRNN 预测误差对比

Table 4 Comparison of prediction errors of CNN and K-Fold GRNN

序号	真实值/mm	CNN		K-Fold GRNN	
		预测值/mm	误差率	预测值/mm	误差率
1	6.99	6.64	-0.050	7.07	0.011
2	2.12	2.08	-0.018	2.40	0.132
3	2.69	2.97	0.104	3.03	0.126
4	8.29	7.31	-0.118	7.98	-0.037
5	4.13	3.74	-0.094	3.85	-0.067
6	4.68	4.69	0.002	4.76	0.017
7	3.83	4.15	0.083	3.97	0.036
8	4.93	5.09	0.032	4.89	-0.008

表 5 两种模型的 MEA 与 RMSE 对比

Table 5 Comparison of MEA and RMSE of two models

神经网络模型	均方差 MEA	均方根误差 RMSE
CNN	0.337 3	0.434 3
K-Fold GRNN	0.223 9	0.265 2

表6 两种预测方法最优精度对比
Table 6 Comparison of the optimal accuracy of two prediction methods

预测方法	均方差	均方根误差
	MEA	RMSE
有限元仿真(城际铁路) ^[7]	0.43	0.31
有限元仿真(高速铁路) ^[6]	0.38	0.28
机器学习(高速铁路)	0.22	0.27

站台门的前期设计与后期维修提供了数据参考和支撑。

4 结论

将高速列车过站时在不同车长、速度,站台不同安装距离及不同阻塞比的210种工况及210种工况下的站台门结构运维数据作为样本数据,采用CNN神经网络和基于K-Fold算法优化的GRNN神经网络,分别建立站台门形变量预测模型,并进行试验和验证。得出如下结论。

(1)基于K-Fold优化的GRNN模型的均方差维持在0.22以内,均方根误差为0.27,优于CNN模型,两种模型均能较好的预测铁路站台门结构运维数据。

(2)基于K-Fold优化的GRNN模型精确度高于传统的有限元仿真分析方式,处于国内相关研究的领先水平,能够较好预测列车过站时的站台门结构形变量,为站台门前期结构与后期运维提供数据参考。

参 考 文 献

- [1] 李燕. PHM技术在京张高速铁路运用检修中的应用研究[J]. 铁道运输与经济, 2022, 44(9): 103-111.
Li Yan. Research on the application of PHM technology in the maintenance of Beijing-Zhangjiakou high-speed railway[J]. Railway Transport and Economy, 2022, 44(9): 103-111.
- [2] 韩运动, 陈大伟, 刘韶庆, 等. 不同风速风向条件下的列车风特性[J]. 中国铁道科学, 2018, 39(6): 104-111.
Han Yundong, Chen Dawei, Liu Shaoqing, et al. Train aerodynamic characteristics under different wind speeds and directions[J]. Chinese Railway Science, 2018, 39(6): 104-111.
- [3] 李新民, 聂小春, 晏致涛, 等. 1 520 mm²大截面两分裂新月形覆冰导线空气动力特性试验研究[J]. 科学技术与工程, 2017, 17(27): 53-58.
Li Xinmin, Nie Xiaochun, Yan Zhitao, et al. Experimental study on the aerodynamic characteristics of 1 520 mm² large cross-section bifurcated crescent-shaped iced conductor[J]. Science Technology and Engineering, 2017, 17(27): 53-58.
- [4] 白雨坤. 城市轨道交通站台门系统的控制与数据处理[D]. 北京: 中国铁道科学研究院, 2014.
Bai Yukun. Control and data processing of platform screen door systems in urban rail transit[D]. Beijing: China Academy of Railway Sciences, 2014.
- [5] 胡振亚, 罗威. 轨道交通站台门轨旁安全设计[J]. 中国安全生产科学技术, 2019, 15(S1): 85-89.
Hu Zhenya, Luo Wei. Safety design for platform screen door trackside in rail transit railways[J]. Science Technology and Engineering Journal of Safety Science and Technology, 2019, 15(S1): 85-89.
- [6] 王志飞. 列车高速过站风压对站台门结构特性的影响[J]. 机械设计与制造, 2020(12): 134-137, 141.
Wang Zhifei. Impact of train pass-by wind pressure on the structural characteristics of platform screen doors at high speed[J]. Machinery Design & Manufacture, 2020(12): 134-137, 141.
- [7] 周梅, 毛良. 城际铁路列车通过地下站台门时的风致效应仿真与试验研究[J]. 现代城市轨道交通, 2023(3): 25-29.
Zhou Mei, Mao Liang. Simulation and experimental study on the wind-induced effects of intercity railway trains passing platform screen doors at underground stations[J]. Modern Urban Transit, 2023(3): 25-29.
- [8] Ali J M, Omar A A, Ali M'B A, et al. Numerical investigation of aerodynamic characteristics of high speed rail [J]. IOP Conference, 2017, 184(1). DOI:10.1088/1757-899X/184/1/012015.
- [9] 肖艳, 王建东, 王振. 基于亲信度的过程信号与报警信号相关性分析[J]. 科学技术与工程, 2020, 20(24): 9930-9936.
Xiao Yan, Wang Jiandong, Wang Zhen. Correlation analysis of process signals and alarm signals based on credibility[J]. Science Technology and Engineering, 2020, 20(24): 9930-9936.
- [10] 曾国治, 魏子清, 岳宝, 等. 基于CNN-RNN组合模型的办公建筑能耗预测[J]. 上海交通大学学报, 2022, 56(9): 1256-1261.
Zeng Guozhi, Wei Ziqing, Yue Bao, et al. Energy consumption prediction for office buildings based on a combined CNN-RNN model[J]. Journal of Shanghai Jiao Tong University, 2022, 56(9): 1256-1261.
- [11] 江佳霖, 钟宝荣. 基于改进Mask R-CNN的高密度砂岩颗粒的分割识别[J]. 科学技术与工程, 2024, 24(9): 3737-3746.
Jiang Jialin, Zhong Baorong. Segmentation and identification of high-density sandstone particles based on improved mask R-CNN [J]. Science Technology and Engineering, 2024, 24(9): 3737-3746.
- [12] 杨雅萍, 张文莲, 孙晓云. 基于改进蝙蝠算法优化广义回归神经网络的岩质边坡稳定性预测[J]. 科学技术与工程, 2021, 21(20): 8719-8726.
Yang Yaping, Zhang Wenlian, Sun Xiaoyun. Prediction of rock slope stability based on generalized regression neural network optimized by improved bat algorithm[J]. Science Technology and Engineering, 2021, 21(20): 8719-8726.
- [13] Makomere S R, Koech L, Rutto L H, et al. Precision forecasting of spray-dry desulfurization using Gaussian noise data augmentation and K-fold cross-validation optimized neural computing[J]. Journal of Environmental Science and Health: Part A, 2024, 59(1): 11-14.